


Umělá inteligence II



Roman Barták, KTIML

roman.bartak@mff.cuni.cz
<http://ktiml.mff.cuni.cz/~bartak>



4

Dnešní program

- Agent pracující v **částečně pozorovatelném prostředí** udržuje na základě **senzorického modelu** domnělý stav a na základě **přechodového modelu** odhaduje, jak se svět může vyvíjet.

- domnělý stav** reprezentuje možné skutečné stavy světa buď výčtově nebo logickou formulí (přes vlastnosti stavu)
- pomocí teorie pravděpodobnosti umíme kvantifikovat, které z domnělých stavů jsou pravděpodobnější
- teď přidáme pravděpodobnost k přechodům mezi stavy


Pravděpodobností uvažování o čase

- reprezentace přechodů s pravděpodobností
- typy řešených úloh (otázek)
- základní odvozovací algoritmy
- temporální modely (skryté Markovské modely, dynamické Bayesovské sítě)



Čas a neurčitost

- Podobně jako v logické reprezentaci sloužil **situační kalkulus**, budeme dynamiku světa modelovat sérií **časových řezů**.
- Každý řez/**stav** bude popsán (stejnou) množinou náhodných proměnných, které se dělí na
 - **nepozorovatelné** náhodné **proměnné** X_t
 - **pozorované** náhodné **proměnné** E_t (konkrétní pozorované hodnoty označíme e_t) t je označení časového řezu (uvažujeme tedy **diskrétní čas** se stejnými časovými kroky)



Notace:

- $X_{a:b}$ označuje množinu proměnných od X_a po X_b

Umělá inteligence II, Roman Barták

Modelová situace

- Uvažujme agenta pracujícího na tajné podzemní základně, ze které nikdy nevychází.
- Zajímá ho, zda venku prší.
 - náhodná nepozorovatelná proměnná R_t
- Jediné pozorování, které má k dispozici, je zda ráno ředitel přišel s či bez deštníku.
 - náhodná pozorovaná proměnná U_t



Umělá inteligence II, Roman Barták


Přechodový model

Přechodový model popisuje, jak je stav ovlivněn předchozími stavy. Přesněji popisuje pravděpodobnostní distribuci $\mathbf{P}(\mathbf{X}_t | \mathbf{X}_{0:t-1})$.

Problém č. 1: s rostoucím t neomezeně roste množina $\mathbf{X}_{0:t-1}$

- použijeme **Markovský předpoklad**: současný stav závisí pouze na pevně daném konečném počtu předchozích stavů – hovoříme potom o obecných **Markovských řetězcích/procesech**
- např. současný stav závisí pouze na předchozím stavu – **Markovský proces prvního řádu**

$$\mathbf{P}(\mathbf{X}_t | \mathbf{X}_{0:t-1}) = \mathbf{P}(\mathbf{X}_t | \mathbf{X}_{t-1})$$



Problém č. 2: pořád máme nekonečně mnoho různých přechodů

- použijeme **předpoklad stacionárního procesu**, tj. stav se vždy mění podle stejných pevně daných pravidel
- distribuce $\mathbf{P}(\mathbf{X}_t | \mathbf{X}_{t-1})$ je stejná pro všechny časy t

Umělá inteligence II, Roman Barták

Senzorický model



Senzorický model popisuje na čem závisí pozorované náhodné proměnné \mathbf{E}_t .

Ty mohou záviset i na proměnných z předchozích stavů, ale uděláme

Markovský senzorický předpoklad – pozorované proměnné závisí pouze na nepozorovatelných proměnných \mathbf{X}_t ze stejného stavu.

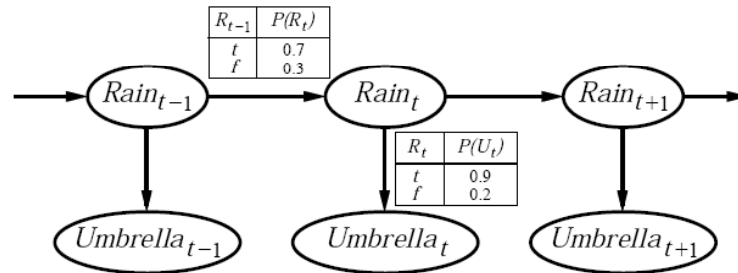
$$\mathbf{P}(\mathbf{E}_t | \mathbf{X}_{0:t}, \mathbf{E}_{1:t-1}) = \mathbf{P}(\mathbf{E}_t | \mathbf{X}_t)$$

Umělá inteligence II, Roman Barták

Bayesovské sítě

pro přechodový a sensorický model

- Přechodový a sensorický model můžeme popsat **Bayesovskou sítí**.
- Kromě tabulek $P(\mathbf{X}_t | \mathbf{X}_{t-1})$ a $P(\mathbf{E}_t | \mathbf{X}_t)$ musíme ještě zadat, jak to vše začalo $P(\mathbf{X}_0)$.



- Z vlastností Bayesovských sítí víme

$$P(\mathbf{X}_{0:t}, \mathbf{E}_{1:t}) = P(\mathbf{X}_0) \prod_i P(\mathbf{X}_i | \mathbf{X}_{i-1}) P(\mathbf{E}_i | \mathbf{X}_i)$$


Umělá inteligence II, Roman Barták

Zpřesnění modelu

Markovský proces prvního řádu předpokládá, že stavové proměnné obsahují veškerou informaci pro charakteristiku pravděpodobnostní distribuce dalšího stavu.

Co když je tento předpoklad nepřesný?

- můžeme **zvýšit řád** Markovského procesu
- můžeme **rozšířit množinu** stavových proměnných
 - např. přidáme proměnnou $Season_t$ nebo sadu proměnných $Temperature_t$, $Humidity_t$, $Pressure_t$
 - první případ (větší řád) lze vždy převést na druhý případ (více proměnných)



Umělá inteligence II, Roman Barták

- **Filtrace:** úloha zjistit pravděpodobnost aktuálního stavu na základě dosavadních pozorování
 $P(\mathbf{X}_t | \mathbf{e}_{1:t})$
- **Predikce:** úloha zjistit pravděpodobnost budoucího stavu na základě dosavadních pozorování
 $P(\mathbf{X}_{t+k} | \mathbf{e}_{1:t})$ pro $k > 0$
- **Vyhlazování:** úloha zjistit pravděpodobnost minulého stavu na základě dosavadních pozorování
 $P(\mathbf{X}_k | \mathbf{e}_{1:t})$ pro $k: 0 \leq k < t$
- **Nejpravděpodobnější průchod:** úloha zjistit z posloupnosti pozorování nejpravděpodobnější posloupnost stavů, která tato pozorování generuje
 $\operatorname{argmax}_{\mathbf{x}_{1:t}} P(\mathbf{x}_{1:t} | \mathbf{e}_{1:t})$



Umělá inteligence II, Roman Barták

Filtrace

- Úkolem je zjistit pravděpodobnost aktuálního stavu na základě dosavadních pozorování – $P(\mathbf{X}_t | \mathbf{e}_{1:t})$.
- Dobrý finanční algoritmus odhaduje aktuální stav z odhadu předchozího stavu a aktuálního pozorování (**rekurzivní odhad**)
 $P(\mathbf{X}_{t+1} | \mathbf{e}_{1:t+1}) = f(\mathbf{e}_{t+1}, P(\mathbf{X}_t | \mathbf{e}_{1:t}))$

Jak najdeme funkci f ?

$$\begin{aligned} P(\mathbf{X}_{t+1} | \mathbf{e}_{1:t+1}) &= P(\mathbf{X}_{t+1} | \mathbf{e}_{1:t}, \mathbf{e}_{t+1}) \\ &= \alpha P(\mathbf{e}_{t+1} | \mathbf{X}_{t+1}, \mathbf{e}_{1:t}) P(\mathbf{X}_{t+1} | \mathbf{e}_{1:t}) \\ &= \alpha P(\mathbf{e}_{t+1} | \mathbf{X}_{t+1}) P(\mathbf{X}_{t+1} | \mathbf{e}_{1:t}) \\ &= \alpha P(\mathbf{e}_{t+1} | \mathbf{X}_{t+1}) \sum_{\mathbf{x}_t} P(\mathbf{X}_{t+1} | \mathbf{x}_t, \mathbf{e}_{1:t}) P(\mathbf{x}_t | \mathbf{e}_{1:t}) \\ &= \alpha P(\mathbf{e}_{t+1} | \mathbf{X}_{t+1}) \sum_{\mathbf{x}_t} P(\mathbf{X}_{t+1} | \mathbf{x}_t) P(\mathbf{x}_t | \mathbf{e}_{1:t}) \end{aligned}$$


Bayesovo pravidlo

Markovský sensorický předpoklad

podmiňování
 $P(\mathbf{Y}) = \sum_z P(\mathbf{Y} | \mathbf{z}) P(\mathbf{z})$


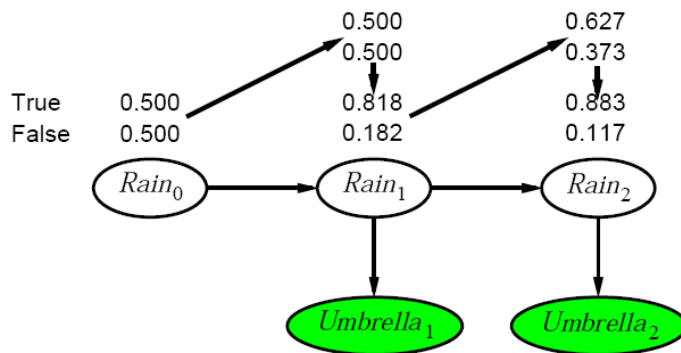
Můžeme tedy použít techniku dopředné propagace zprávy:

$$\begin{aligned} P(\mathbf{X}_t | \mathbf{e}_{1:t}) &= \mathbf{f}_{1:t} \\ \mathbf{f}_{1:t+1} &= \alpha \text{FORWARD}(\mathbf{f}_{1:t}, \mathbf{e}_{t+1}) \\ \mathbf{f}_{1:0} &= P(\mathbf{X}_0) \end{aligned}$$



Umělá inteligence II, Roman Barták

$$P(\mathbf{R}_{t+1} | \mathbf{u}_{1:t+1}) = \alpha P(\mathbf{u}_{t+1} | \mathbf{R}_{t+1}) P(\mathbf{R}_{t+1} | \mathbf{u}_{1:t}) = \alpha P(\mathbf{u}_{t+1} | \mathbf{R}_{t+1}) \sum_{r_t} P(\mathbf{R}_{t+1} | r_t) P(r_t | \mathbf{u}_{1:t})$$



$$P(\mathbf{R}_0) = \langle 0.5, 0.5 \rangle$$

$$P(\mathbf{R}_1) = \sum_{r_0} P(\mathbf{R}_1 | r_0) P(r_0) = \langle 0.5, 0.5 \rangle$$

$$P(\mathbf{R}_1 | \mathbf{u}_1) = \alpha P(\mathbf{u}_1 | \mathbf{R}_1) P(\mathbf{R}_1) = \alpha \langle 0.9, 0.2 \rangle \langle 0.5, 0.5 \rangle \approx \langle 0.818, 0.182 \rangle$$

$$P(\mathbf{R}_2 | \mathbf{u}_1) = \sum_{r_1} P(\mathbf{R}_2 | r_1) P(r_1 | \mathbf{u}_1) = \langle 0.7, 0.3 \rangle \times 0.818 + \langle 0.3, 0.7 \rangle \times 0.182 \approx \langle 0.627, 0.372 \rangle$$

$$P(\mathbf{R}_2 | \mathbf{u}_1, \mathbf{u}_2) = \alpha P(\mathbf{u}_2 | \mathbf{R}_2) P(\mathbf{R}_2 | \mathbf{u}_1) = \alpha \langle 0.9, 0.2 \rangle \langle 0.627, 0.372 \rangle = \langle 0.883, 0.117 \rangle$$

Umělá inteligence II, Roman Barták

Predikce

- Úkolem je zjistit pravděpodobnost budoucího stavu na základě dosavadních pozorování – $P(\mathbf{X}_{t+k} | \mathbf{e}_{1:t})$ pro $k > 0$.
- Jedná se v podstatě o filtraci bez přidávání dalších pozorování

$$P(\mathbf{X}_{t+k+1} | \mathbf{e}_{1:t}) = \sum_{\mathbf{x}_{t+k}} P(\mathbf{X}_{t+k+1} | \mathbf{x}_{t+k}) P(\mathbf{x}_{t+k} | \mathbf{e}_{1:t})$$

- Po určité době (**mixing time**) konverguje předpovězená distribuce ke stacionární distribuci a nadále zůstane stejná.



Umělá inteligence II, Roman Barták

Vyhlazování

- Úkolem je zjistit pravděpodobnost minulého stavu na základě dosavadních pozorování – $\mathbf{P}(\mathbf{X}_k | \mathbf{e}_{1:t})$ pro $k: 0 \leq k < t$.
- Opět použijeme rekurzivní předávání zpráv, tentokrát ve dvou směrech.

$$\begin{aligned} \mathbf{P}(\mathbf{X}_k | \mathbf{e}_{1:t}) &= \mathbf{P}(\mathbf{X}_k | \mathbf{e}_{1:k}, \mathbf{e}_{k+1:t}) \\ &= \alpha \mathbf{P}(\mathbf{X}_k | \mathbf{e}_{1:k}) \mathbf{P}(\mathbf{e}_{k+1:t} | \mathbf{X}_k, \mathbf{e}_{1:k}) \\ &= \alpha \mathbf{P}(\mathbf{X}_k | \mathbf{e}_{1:k}) \mathbf{P}(\mathbf{e}_{k+1:t} | \mathbf{X}_k) \\ &= \alpha \mathbf{f}_{1:k} \times \mathbf{b}_{k+1:t} \end{aligned}$$

Bayesovo pravidlo

podmíněná nezávislost

$$\begin{aligned} \mathbf{P}(\mathbf{e}_{k+1:t} | \mathbf{X}_k) &= \sum_{\mathbf{x}_{k+1}} \mathbf{P}(\mathbf{e}_{k+1:t} | \mathbf{X}_k, \mathbf{x}_{k+1}) \mathbf{P}(\mathbf{x}_{k+1} | \mathbf{X}_k) \\ &= \sum_{\mathbf{x}_{k+1}} \mathbf{P}(\mathbf{e}_{k+1:t} | \mathbf{x}_{k+1}) \mathbf{P}(\mathbf{x}_{k+1} | \mathbf{X}_k) \\ &= \sum_{\mathbf{x}_{k+1}} \mathbf{P}(\mathbf{e}_{k+1}, \mathbf{e}_{k+2:t} | \mathbf{x}_{k+1}) \mathbf{P}(\mathbf{x}_{k+1} | \mathbf{X}_k) \\ &= \sum_{\mathbf{x}_{k+1}} \mathbf{P}(\mathbf{e}_{k+1} | \mathbf{x}_{k+1}) \mathbf{P}(\mathbf{e}_{k+2:t} | \mathbf{x}_{k+1}) \mathbf{P}(\mathbf{x}_{k+1} | \mathbf{X}_k) \end{aligned}$$


podmiňování

podmíněná nezávislost

podmíněná nezávislost

Popíšeme jako zpětnou propagaci zprávy:

$$\begin{aligned} \mathbf{P}(\mathbf{e}_{k+1:t} | \mathbf{X}_k) &= \mathbf{b}_{k+1:t} \\ \mathbf{b}_{k+1:t} &= \text{BACWARD}(\mathbf{b}_{k+2:t}, \mathbf{e}_{k+1}) \\ \mathbf{b}_{t+1:t} &= \mathbf{P}(\mathbf{e}_{t+1:t} | \mathbf{X}_t) = \mathbf{P}(|\mathbf{X}_t) = \mathbf{1} \end{aligned}$$



Umělá inteligence II, Roman Barták

Vyhlazování


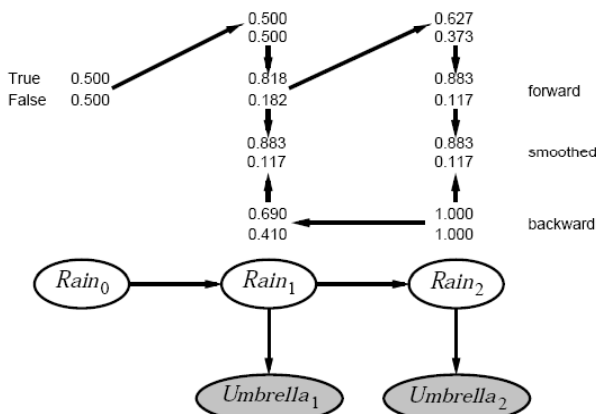
příklad

$$\mathbf{P}(R_k | u_{1:t+1}) = \alpha \mathbf{P}(R_k | u_{1:k}) \mathbf{P}(u_{k+1:t} | R_k)$$

$$\mathbf{P}(u_{k+1:t} | R_k) = \sum_{r_{k+1}} \mathbf{P}(u_{k+1} | r_{k+1}) \mathbf{P}(u_{k+2:t} | r_{k+1}) \mathbf{P}(r_{k+1} | R_k)$$

$$\mathbf{P}(R_2) = \mathbf{1}$$


$$\begin{aligned} \mathbf{P}(u_2 | R_1) &= \sum_{r_2} \mathbf{P}(u_2 | r_2) \mathbf{P}(r_2 | R_1) \\ &= 0.9 \times 1 \times \langle 0.7, 0.3 \rangle + 0.2 \times 1 \times \langle 0.3, 0.7 \rangle = \langle 0.69, 0.41 \rangle \end{aligned}$$



Umělá inteligence II, Roman Barták

Nejpravděpodobnější průchod

- Úkolem je zjistit z posloupnosti pozorování nejpravděpodobnější posloupnost stavů, která tato pozorování generuje – $\operatorname{argmax}_{x_{1:t}} P(x_{1:t} | \mathbf{e}_{1:t})$.
- Pozor, je to něco jiného než zjistit posloupnost nejpravděpodobnějších stavů!
- Na problém se můžeme podívat takto:
 - **hledáme cestu v grafu**, kde uzly odpovídají možným stavům v každém časovém kroku



- díky Markovské vlastnosti víme, že nejpravděpodobnější cesta do daného stavu se skládá z nejpravděpodobnější cesty do některého předchůdce a přechodu do daného stavu
- tuto vlastnost opět můžeme popsat **rekurzivně**

Umělá inteligence II, Roman Barták


Viterbiho algoritmus

- nejpravděpodobnější cesta do daného stavu se skládá z nejpravděpodobnější cesty do některého předchůdce a přechodu do daného stavu

$$\begin{aligned} & \max_{x_1, \dots, x_t} P(x_1, \dots, x_t, X_{t+1} | \mathbf{e}_{1:t+1}) \\ & = \alpha P(\mathbf{e}_{t+1} | X_{t+1}) \max_{x_t} (P(X_{t+1} | x_t) \max_{x_1, \dots, x_{t-1}} P(x_1, \dots, x_{t-1} | \mathbf{e}_{1:t})) \end{aligned}$$

- použijeme techniku dopředné propagace zprávy:

$$\begin{aligned} m_{1:t} &= \max_{x_1, \dots, x_{t-1}} P(x_1, \dots, x_{t-1}, X_t | \mathbf{e}_{1:t}) \\ m_{1:t+1} &= P(\mathbf{e}_{t+1} | X_{t+1}) \max_{x_t} (P(X_{t+1} | x_t) m_{1:t}) \end{aligned}$$



Umělá inteligence II, Roman Barták

Skryté Markovské modely

- Uvažujme, že stav světa je popsán jedinou náhodnou proměnnou X_t (podobně pozorovaná proměnná E_t bývá jediná).
- Hovoříme potom o **skrytém** (částečně pozorovaném) **Markovském modelu** (HMM – Hidden Markov Model).
- Pro takový speciální případ můžeme **úlohy** řešit efektivně **pomocí maticových operací**.
- Uvažujme, že proměnná X_t nabývá hodnoty z množiny $\{1, \dots, S\}$, tj. S je počet možných stavů světa.
 - pravděpodobnostní tabulku $\mathbf{P}(X_t | X_{t-1})$ pro **přechody** lze popsat maticí \mathbf{T} o rozměrech $S \times S$, kde:

$$\mathbf{T}_{(i,j)} = P(X_t = j | X_{t-1} = i)$$

- podobně můžeme popsat tabulku pro **pozorování**, kde využijeme toho, že konkrétní pozorování e_t známe, takže popisujeme $P(E_t = e_t | X_t = i)$, použijeme diagonální matici \mathbf{O}_t , kde:

$$\mathbf{O}_{t(i,i)} = P(E_t = e_t | X_t = i)$$

Umělá inteligence II, Roman Barták

Maticový přístup

- **Dopředné zprávy** (z filtrace)
 - $\mathbf{P}(X_t | \mathbf{e}_{1:t}) = \mathbf{f}_{1:t}$
 - $\mathbf{f}_{1:t+1} = \alpha \mathbf{P}(\mathbf{e}_{t+1} | \mathbf{X}_{t+1}) \sum_{\mathbf{x}_t} \mathbf{P}(\mathbf{X}_{t+1} | \mathbf{x}_t) \mathbf{P}(\mathbf{x}_t | \mathbf{e}_{1:t})$
- Pomocí matic (uvažujme, že zpráva $\mathbf{f}_{1:t}$ je ve tvaru jednoho sloupce)
 - $\mathbf{T}_{(i,j)} = P(X_t = j | X_{t-1} = i)$
 - $\mathbf{O}_{t(i,i)} = P(E_t = e_t | X_t = i)$
 - $\mathbf{f}_{1:t+1} = \alpha \mathbf{O}_{t+1} \mathbf{T}^T \mathbf{f}_{1:t}$
- **Zpětné zprávy** (z vyhlazování)
 - $\mathbf{P}(\mathbf{e}_{k+1:t} | \mathbf{X}_k) = \mathbf{b}_{k+1:t}$
 - $\mathbf{b}_{k+1:t} = \sum_{\mathbf{x}_{k+1}} P(\mathbf{e}_{k+1} | \mathbf{x}_{k+1}) P(\mathbf{e}_{k+2:t} | \mathbf{x}_{k+1}) \mathbf{P}(\mathbf{x}_{k+1} | \mathbf{X}_k)$
- Pomocí matic (uvažujme, že zpráva $\mathbf{b}_{k:t}$ je ve tvaru jednoho sloupce)
 - $\mathbf{b}_{k+1:t} = \mathbf{T} \mathbf{O}_{k+1} \mathbf{b}_{k+2:t}$

Umělá inteligence II, Roman Barták

Úplné vyhlazování

- Při vyhlazování nám typicky nejde pouze o jednu proměnnou, ale o **vyhlazení všech proměnných najednou**.

$$P(\mathbf{X}_k | \mathbf{e}_{1:t}) = \alpha \mathbf{f}_{1:k} \times \mathbf{b}_{k+1:t}$$

- pro vyhlazení jedné proměnné vzhledem k $\mathbf{e}_{1:t}$ potřebujeme čas $O(t)$
- triviální algoritmus tedy postup vyhlazení opakuje pro všechny proměnné – čas $O(t^2)$
- lepší přístup používá **dynamické programování**, tj. pamatujeme si dopředné zprávy a při zpětném průchodu je spojíme se zpětnými zprávami – čas $O(t)$
 - **algoritmus forward-backward**
 - nevýhodou přístupu je prostorová složitost $O(|\mathbf{f}|t)$

Umělá inteligence II, Roman Barták

Úplné vyhlazování

algoritmus forward-backward

function FORWARD-BACKWARD(**ev**, **prior**) **returns** a vector of probability distributions

inputs: **ev**, a vector of evidence values for steps $1, \dots, t$

prior, the prior distribution on the initial state, $P(\mathbf{X}_0)$

local variables: **fv**, a vector of forward messages for steps $0, \dots, t$

b, a representation of the backward message, initially all 1s

sv, a vector of smoothed estimates for steps $1, \dots, t$

fv[0] \leftarrow *prior*

for $i = 1$ **to** t **do**

fv[i] \leftarrow FORWARD(**fv**[$i - 1$], **ev**[i])

for $i = t$ **downto** 1 **do**

sv[i] \leftarrow NORMALIZE(**fv**[i] \times **b**)

b \leftarrow BACKWARD(**b**, **ev**[i])

return **sv**

Umělá inteligence II, Roman Barták

Úplné vyhlazování

efektivně

Můžeme úplné vyhlazení udělat s menšími paměťovými nároky při zachování časové složitosti $O(t)$?

Idea:

- pokud bychom uměli výpočet udělat pouze v jednom směru, stačí nám konstantní paměť (nezávislá na t)
- můžeme zprávu $\mathbf{f}_{1:t}$ získat ze zprávy $\mathbf{f}_{1:t+1}$?
- potom bychom mohli „dopřednou“ zprávu propagovat stejně jako „zpětnou zprávu“

Použijeme **maticový přístup**

$$\mathbf{f}_{1:t+1} = \alpha \mathbf{O}_{t+1} \mathbf{T}^T \mathbf{f}_{1:t} \quad \rightarrow \quad \mathbf{f}_{1:t} = \alpha^{-1} (\mathbf{T}^T)^{-1} (\mathbf{O}_{t+1})^{-1} \mathbf{f}_{1:t+1}$$

Algoritmus

- nejprve dopředným průchodem vypočteme $\mathbf{f}_{1:t}$
- potom při zpětném chodu dohromady počítáme $\mathbf{f}_{1:k}$ a $\mathbf{b}_{k+1:t}$

Umělá inteligence II, Roman Barták

vyhlazování se zpožděním

- Uvažujme nyní případ, kde nás zajímá hodnota $\mathbf{P}(\mathbf{X}_{t-d} | \mathbf{e}_{1:t})$ s pevně daným zpožděním d , tzv. **vyhlazování s konstantním zpožděním**.
- Ideálně chceme, aby výpočet při zvětšení t fungoval inkrementálně tj. v konstantním čase.
 - máme $\mathbf{P}(\mathbf{X}_{t-d} | \mathbf{e}_{1:t}) = \alpha \mathbf{f}_{1:t-d} \times \mathbf{b}_{t-d+1:t}$
 - chceme $\mathbf{P}(\mathbf{X}_{t-d+1} | \mathbf{e}_{1:t+1}) = \alpha \mathbf{f}_{1:t-d+1} \times \mathbf{b}_{t-d+2:t+1}$

Inkrementální postup:

- umíme $\mathbf{f}_{1:t-d+1} = \alpha \mathbf{O}_{t-d+2} \mathbf{T}^T \mathbf{f}_{1:t-d}$
- potřebujeme inkrementální výpočet $\mathbf{b}_{t-d+2:t+1}$ z $\mathbf{b}_{t-d+1:t}$
 - $\mathbf{b}_{t-d+1:t} = \mathbf{T} \mathbf{O}_{t-d+1} \mathbf{b}_{t-d+2:t} = (\prod_{i=t-d+1, \dots, t} \mathbf{T} \mathbf{O}_i) \mathbf{b}_{t+1:t} = \mathbf{B}_{t-d+1:t} \mathbf{1}$
 - $\mathbf{b}_{t-d+2:t+1} = (\prod_{i=t-d+2, \dots, t+1} \mathbf{T} \mathbf{O}_i) \mathbf{b}_{t+2:t+1} = \mathbf{B}_{t-d+2:t+1} \mathbf{1}$
 - $\mathbf{B}_{t-d+2:t+1} = (\mathbf{O}_{t-d+1})^{-1} \mathbf{T}^{-1} \mathbf{B}_{t-d+1:t} \mathbf{T} \mathbf{O}_{t+1}$

Umělá inteligence II, Roman Barták

Vyhazování se zpožděním

algorithmus

```
function FIXED-LAG-SMOOTHING( $e_t$ , hmm,  $d$ ) returns a distribution over  $\mathbf{X}_{t-d}$ 
inputs:  $e_t$ , the current evidence for time step  $t$ 
          hmm, a hidden Markov model with  $S \times S$  transition matrix  $T$ 
           $d$ , the length of the lag for smoothing
static:  $t$ , the current time, initially 1
           $\mathbf{f}$ , a probability distribution, the forward message  $\mathbf{P}(X_t|e_{1:t})$ , initially  $\text{PRIOR}[hmm]$ 
           $B$ , the  $d$ -step backward transformation matrix, initially the identity matrix
           $e_{t-d:t}$ , double-ended list of evidence from  $t-d$  to  $t$ , initially empty
local variables:  $\mathbf{O}_{t-d}$ ,  $\mathbf{O}_t$ , diagonal matrices containing the sensor model information

add  $e_t$  to the end of  $e_{t-d:t}$ 
 $\mathbf{O}_t \leftarrow$  diagonal matrix containing  $\mathbf{P}(e_t|X_t)$ 
if  $t > d$  then
   $\mathbf{f} \leftarrow \text{FORWARD}(\mathbf{f}, e_t)$ 
  remove  $e_{t-d-1}$  from the beginning of  $e_{t-d:t}$ 
   $\mathbf{O}_{t-d} \leftarrow$  diagonal matrix containing  $\mathbf{P}(e_{t-d}|X_{t-d})$ 
   $B \leftarrow \mathbf{O}_{t-d}^{-1} \mathbf{T}^{-1} \mathbf{B} \mathbf{T} \mathbf{O}_t$ 
else  $B \leftarrow \mathbf{B} \mathbf{T} \mathbf{O}_t$ 
 $t \leftarrow t + 1$ 
if  $t > d$  then return  $\text{NORMALIZE}(\mathbf{f} \times \mathbf{B} \mathbf{1})$  else return null
```

Umělá inteligence II, Roman Barták

Lokalizace

příklad

- Uvažujme případ, kdy náhodně pohybující se agent má mapu světa, senzory ukazující okolí a potřebuje zjistit, kde se nachází.

Model:

- **náhodná proměnná** X_t popisuje lokaci v čase t
 - možné hodnoty $1, \dots, n$ pro n možných pozic
 - $Nb(i)$ – množina pozic v okolí pozice i , kam agent může přejít
- **přechodová tabulka**
 - $P(X_{t+1}=j|X_t=i) = 1/|Nb(i)|$, pokud $j \in Nb(i)$, jinak 0
- **senzorická proměnná** E_t popisuje výsledek pozorování okolí (čtyři senzory NSEW)
 - hodnoty popisují přítomnost překážky NSEW (16 hodnot)
 - uvažujme chybovost senzoru ε
- **senzorická tabulka**
 - $P(E_t=e_t|X_t=i) = (1-\varepsilon)^{4-d_{it}} \varepsilon^{d_{it}}$
kde d_{it} je počet odchylek pozorování e_t od skutečného okolí pozice i




Umělá inteligence II, Roman Barták





Lokalizace

ukázka

$$P(X_1 | E_1 = \text{NSW})$$



$$P(X_2 | E_1 = \text{NSW}, E_2 = \text{NS})$$



chyba lokalizace
(Manhattanská vzdálenost)